

基于深度学习的电动机故障诊断

课程报告

班级：信研 2308 班

姓名：何怡怡

学号：2023200839

第1章 绪论

传统的电动机故障诊断技术通常基于单一类型的状态参数，如振动参数或电气参数等。然而，单一类型的电动机状态参数监测范围很多时候都是非常有限的，难以满足对电动机进行全面综合故障诊断的需求。本文的研究旨在通过融合振动数据和电流数据两种类型的参数，提出一种综合的电动机故障诊断方法，以提高诊断的可靠性和准确性。并在数据融合的基础上考虑到在实际工业和生产环境中，获取大规模标记样本的成本往往较高，甚至不可行。因此，对神经网络进行进一步的学习与改进，提出基于 RNN 和注意力机制的小样本故障诊断网络。

本文利用电动机故障特征提取方法，研究电动机在不同故障下的振动及电流信号特征，所采用的故障特征提取方法包括：快速傅里叶变换 (FFT)和希尔伯特-黄变换。

根据本文的实际数据融合需求，设计数据融合整体实施方案，依次利用快速傅里叶变换（FFT）、希尔伯特-黄变换（HHT）以及卷积神经网络(CNN)串联多层感知机(MLP)等方法提取故障特征，融合电动机的振动及电流参数，对电动机进行综合故障识别与故障诊断。结果表明，采用数据融合方法的电动机故障诊断技术能够提高诊断结果的准确性，减少由于单一参数造成的不确定性，从而提高电动机故障诊断的准确性。设计的小样本故障诊断网络用于识别小样本下设备的健康状态，其中注意力机制捕捉信号的空间和通道关系，利用单一实验样本验证本文使用的网络在不同的小样本工作条件下具有诊断效率和准确率优势。

第 2 章 卷积神经网络

2.1 卷积层

卷积层是卷积神经网络（CNN）中的关键组成部分，用于特征提取。其中，卷积核是卷积层中最关键的元素，它负责对输入信号进行卷积运算，从而提取并生成相应的特征，卷积核的大小和形状是事先确定的，并且在训练过程中会自动学习到适合特定任务的权重参数，因此卷积核的设计可以根据任务的需求进行调整。在卷积神经网络中，每个卷积层通常包含多个卷积核，每个卷积核都可以提取不同的特征。通过在训练过程中优化卷积核的权重参数，网络可以自动学习到对输入数据最有信息量的特征表示，具体的卷积过程可以表示为以下公式：

$$Z_n = W_n * X_{n-1} + b_n$$

$$X_n = \sigma(Z_n) = \sigma(W_n * X_{n-1} + b_n)$$

式中，n表示第n层卷积层；$*$表示卷积运算；b表示偏置参数；W表示卷积核；σ表示激活函数。

卷积运算过程如图 2-1 所示：

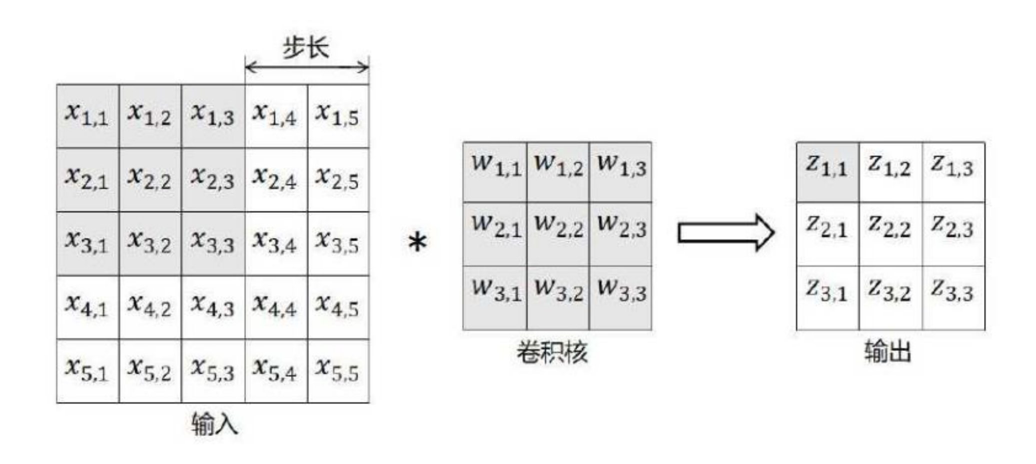


图 2-1 卷积运算过程图

卷积核的使用使得卷积神经网络能够自动从原始输入数据中提取出具有判别性的特征，这些特征对于任务的执行具有重要意义，通过堆叠多个卷积层，网络可以逐渐提取更高级别的特征，实现对复杂模式和抽象概念的理解和表达。

2.2 池化层

池化层是卷积神经网络的重要组成部分，常常与卷积层交替使用来提取特征，池化层通过对输入特征图的局部区域进行汇聚操作，将该区域的信息进行压缩和摘要，输出汇聚后的特征，其主要作用有：

1、降低空间维度: 通过对输入特征进行池化操作，减小了特征的空间尺寸，减少了网络的计算量

2、提取关键特征:池化层对输入的局部区域进行汇聚，保留了最显著的特征，有助于提取最主要的特征

3、平移不变性: 池化操作对输入的平移具有不变性，即输入发生平移时，池化层的输出不会受到影响，增强了网络的平移不变性

但池化操作没有可训练的参数，它只是一种固定的操作，不会引入额外的模型参数。在网络的后续层中，可以进一步添加卷积层和池化层，以提取更高级的特征。

主要的两种类型的池化操作：最大池化（Max Pooling）和平均池化（Average Pooling），如图 2-2：

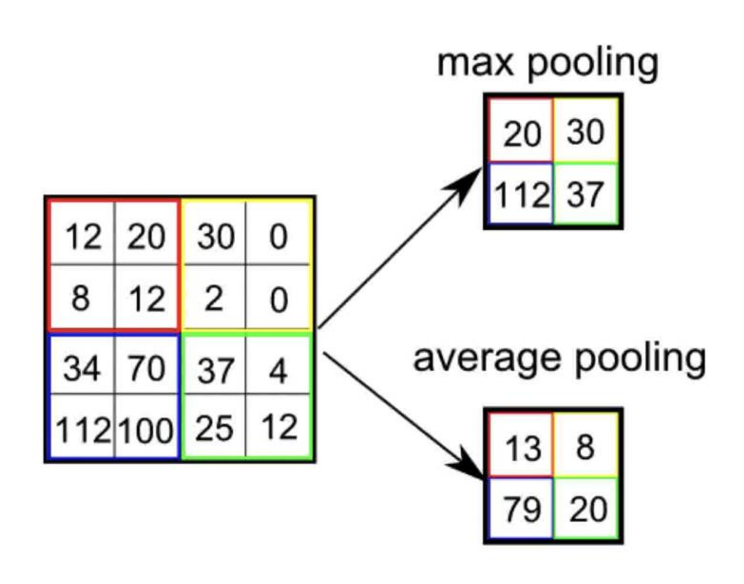


图 2-2 池化原理图

操作原理如下：

1.池化层将输入特征图划分为不重叠的矩形区域 (池化窗口)

2.对于每个池化窗口，选择窗口内的最大值（Max Pooling）/平均值（Average Pooling）作为输出特征

3 输出特征图的尺寸缩小，但保留了输入特征图中最显著的特征。

2.3 激活函数

在一维卷积神经网络中，激活函数通常被应用于卷积层的输出上，以增强网络的非线性能力。一些常见的激活函数包括 ReLu、Sigmod、Tanh 等。

激活函数的作用是对输入进行非线性变换，使得网络可以学习更复杂的模式。

ReLu（Rectified Linear Unit）是一种非常常用的激活函数，其公式为：

$$Relu(x) = max(0, x)$$

其中，$max(0, x)$表示取x和 0 中的较大值，即将所有的负数变为 0，保留所有非负数。ReLu 激活函数具有便于使用、计算效率高和收敛速度快等优点，在深度学习中被广泛使用。

2.4 全连接层

在卷积神经网络中，全连接层 (Fully Connected Layer) 通常位于卷积层和输出层之间，将卷积层或池化层提取的特征进行整合和映射，输出最终的分类结果或回归预测，它是卷积神经网络中重要的组成部分，能够提供对输入数据的全局理解和整体建模能力。运算过程如图 2-3，主要作用是进行特征的非线性映射和组合，从而更好地拟合数据，可以捕捉到输入特征之间的复杂关系，并通过学习适当的权重和偏置来提取更高级的特征。

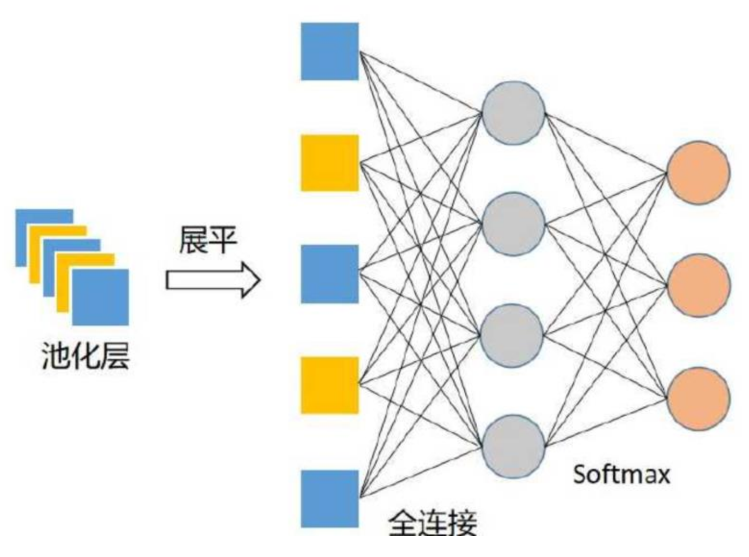


图 2-3 全连接运算过程图

全连接层通常使用激活函数来引入非线性性，用于增加网络的表示能力，在卷积神经网络的训练过程中，全连接层的权重和偏置是可训练的参数，通过反向传播算法和优化器来更新这些参数，以最小化损失函数，使网络能够更好地拟合训练数据。

2.5 多层感知机算法原理

多层感知机（Multilayer Perceptron，MLP）是一种基本的前馈神经网络模型，广泛应用于机器学习和深度学习任务中，它由输入层、输出层和一个或多个隐藏层组成，每一层都由多个神经元（或节点）组成，并通过连接权重进行信息传递，其基本结构如图 2-4 所示:

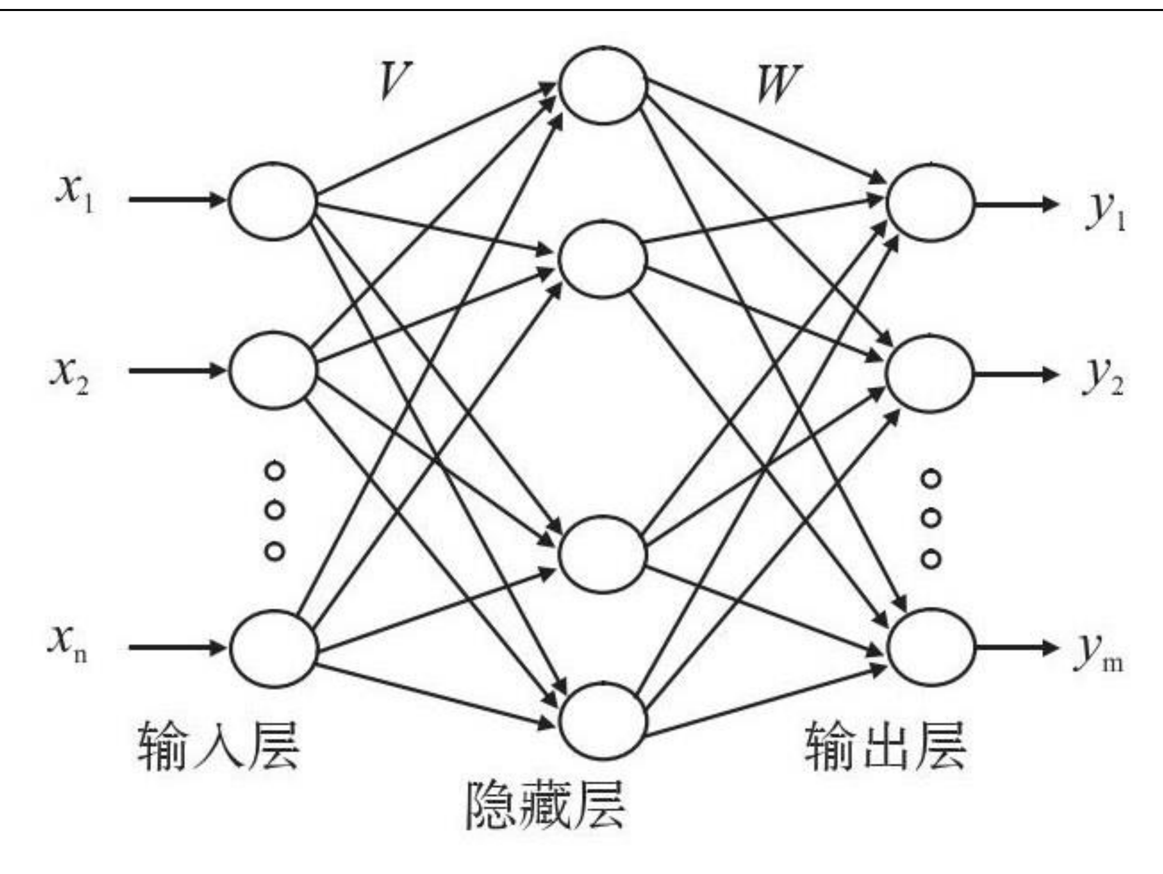


图 2-4 多层感知机结构图

输入层: 接收输入数据的层，每个神经元对应输入向量中的一个特征。假设输入层有 n 个神经元（对应 n 维特征），输入向量为 x = $(x_1, x_2, \ldots, x_n)$

隐藏层: 隐藏层是多层感知机（MLP）中介于输入层和输出层之间的一层或多层，它的主要作用是通过对输入数据进行一系列的非线性变换和特征提取，从而将输入数据映射到更高维的表示空间，它接收来自前一层神经元的输出，并通过连接权重对输入进行加权求和，然后将加权求和的结果经过激活函数进行非线性变换，得到隐藏层神经元的输出。这个过程可以表示为以下公式： $z_j = f\left(v_{j1}x_1 + v_{j2}x_2 + \cdots + v_{jn}x_n + b_j\right)$

其中，$v_{j1}, v_{j2}, ..., v_{jn}$是连接输入层和隐藏层的权重，$b_j$是第 j 个神经元的偏置项，$f(\cdot)$是激活函数。

输出层: 输出神经网络的结果，其中的每个神经元对应一个类别或一个值，输出层的神经元数量取决于问题的类型。这个过程可以表示为以下公式：

$$\mathrm{y_k} = \mathrm{g}(\mathrm{w_{k1}}\, \mathrm{z_1} + \mathrm{w_{k2}}\, \mathrm{z_2} + \cdots + \mathrm{w_{km}}\, \mathrm{z_m} + \mathrm{c_k})$$

其中，$w_{\mathrm{k}1}, w_{\mathrm{k}2}, \ldots, w_{\mathrm{k}m}$是连接隐藏层和输出层的权重，$c_{\mathrm{k}}$是第 k 个神经元的偏置项，$g(\cdot)$是激活函数。

MLP 通过反向传播算法来进行训练，即通过(Backpropagation)最小化损失函数来调整权重和偏置的值。常用的损失函数包括均方误差损失函数、交叉熵损失函数等，反向传播算法通过计算损失函数对权重和偏置的梯度，然后根据梯度更新参数的值，以使损失函数最小化.

总结起来，多层感知机是一种前馈神经网络，通过多个隐藏层和激活函数实现非线性映射，最后通过输出层的 softmax 函数生成预测结果。

通过反向传播算法，可以训练网络参数使得损失函数最小化，从而实现对输入数据的有效建模和分类。

第 3 章　融合方法设计及实验数据分析与验证

3.1 电动机故障数据介绍

109 实验台采集到三相异步电动机故障数据，其中故障模拟试验台概貌及传感器布置如图 3-1：

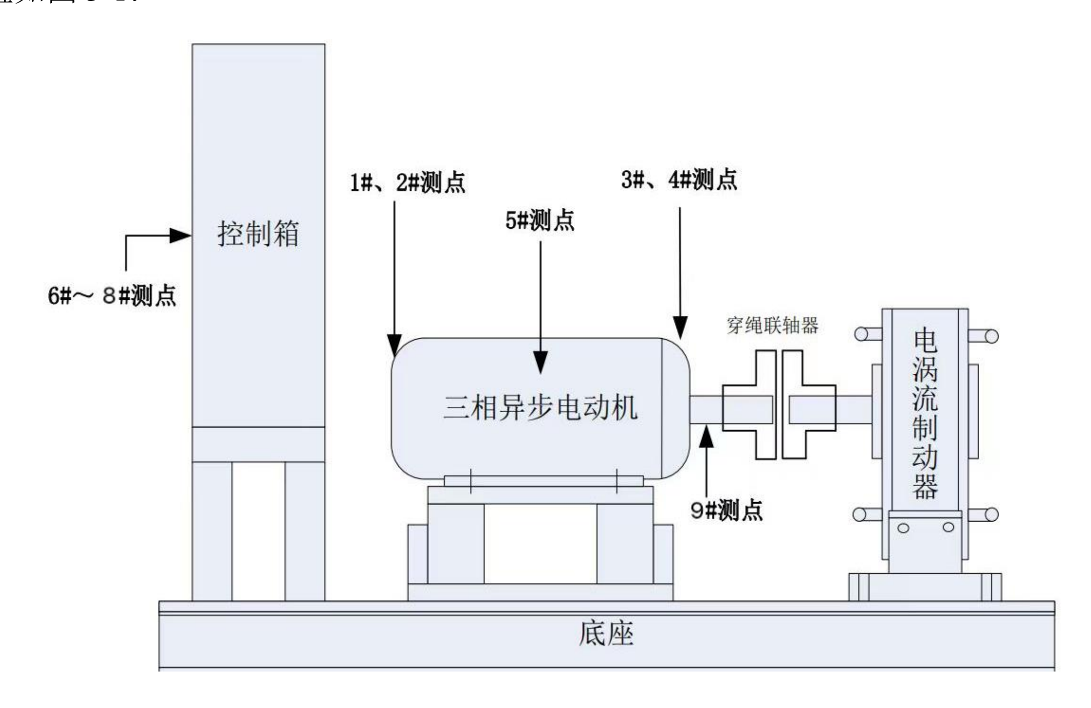


图 3-1 故障模拟实验台概貌及传感器（振动、电流）布置示意图

测点具体说明如下表所示：

表 3-1. 电动机测点说明

序号	测点
①	电机自由端轴承水平测点（振动）
②	电机自由端轴承垂直测点（振动）
③	电机驱动端轴承水平测点（振动）
④	电机驱动端轴承垂直测点（振动）

⑤	电机壳体垂直测点（振动）
⑥	电机 A 相电流测点
⑦	电机 B 相电流测点
⑧	电机 C 相电流测点
⑨	电机转速测点

电机的具体信息如下表：

表 3-2. 电机参数表

额定功率	额定电流	额定转速	额定转矩	转子导条数	定子槽数	磁极数
3kW	6.31A	2860rpm	10N•m	20	24	2

采集的数据包含：正常运行（norm）、转子断条故障（Broken_RotorBar）、动态偏心（Dynamic_eccentricity）、静态偏心（Static_eccentricity）、轴承保持架（Bearing_cage）、轴承内圈（Bearing_innerring）、轴承外圈（Bearing_outerring）故障。

采样频率为：40960Hz（除了静态偏心 Static_eccentricity 为 12800Hz 外），数据工况均为电源频率为 50Hz，100%工况（满载），实际转速为 2870rpm 左右。

3.2 数据融合与故障诊断整体方案设计

电机故障诊断中常用监测方法有振动监测与电气监测，两种监测方法基本可以覆盖电机常见的大部分机械和电气类故障，因此本文电机数据融合主要采用振动数据和电流数据，对电动机进行故障识别与故障诊断。

本文电机数据融合主要采用同一时间不同空间下、并联、特征级融合的融合方式对电机振动及电流数据进行融合，数据融合整体技术流程如图 所示，主要包含以下步骤：

1、数据集的故障机理及特征的研究学习。

2、特征值提取；利用希尔伯特-黄变换（HHT）提取振动数据包络谱作为特征

值，利用快速傅里叶变换(FFT)提取电流数据频谱作为特征值，划分训练集和测试集。

3、神经网络融合及识别；将训练集数据输入到建立好的神经网络中训练网络，将测试集数据输入到已学习训练完成的网络中，输出判断结果，并统计其准确率。

4、单独使用振动数据、电流数据，进行同样的步骤，分别观察准确率，评判融合网络的效果。

3.3 数据故障特征提取

3.3.1 故障特征提取方案设计

电流数据通常包含周期性和瞬时性的信息，而振动数据可能包含频率和幅度变化的信息，因而理论上讲，对于电流数据的处理，使用 FFT 可以将电流信号转换到频域，提取出频谱信息，用于分析电流信号中的频率成分，通过分析频谱，可以检测到电流信号中存在的频率异常或共振现象，从而识别电动机的故障特征；对于振动数据的处理，使用 HHT 方法能够将振动信号进行时频域分析，捕捉信号在不同时间和频率上的变化特征，提取出振动信号的瞬时频率、能量分布以及时频特性，有助于识别电动机振动信号中的异常振动模式和故障特征。

于是针对故障提取方式的选择与验证，设计了以下三种方案：

1、对振动和电流数据均使用 FFT 求取频谱作为故障特征

2、对振动和电流数据均使用 HHT 求取包络谱作为故障特征

3、对振动数据使用 HHT 求取包络谱，对电流数据使用 FFT 求取频谱作为故障特征

待具体的数据融合方法设计出后进行验证方案三是否是最优选择。

3.3.2 原始故障数据及特征提取展示

正常状态、动态偏心故障，转子断条故障、轴承保持架故障、轴承内圈故障以及轴承外圈故障的振动、电流波形图、FFT 频谱图和 HHT 包络图如图 3-2 及 3-3 所示：

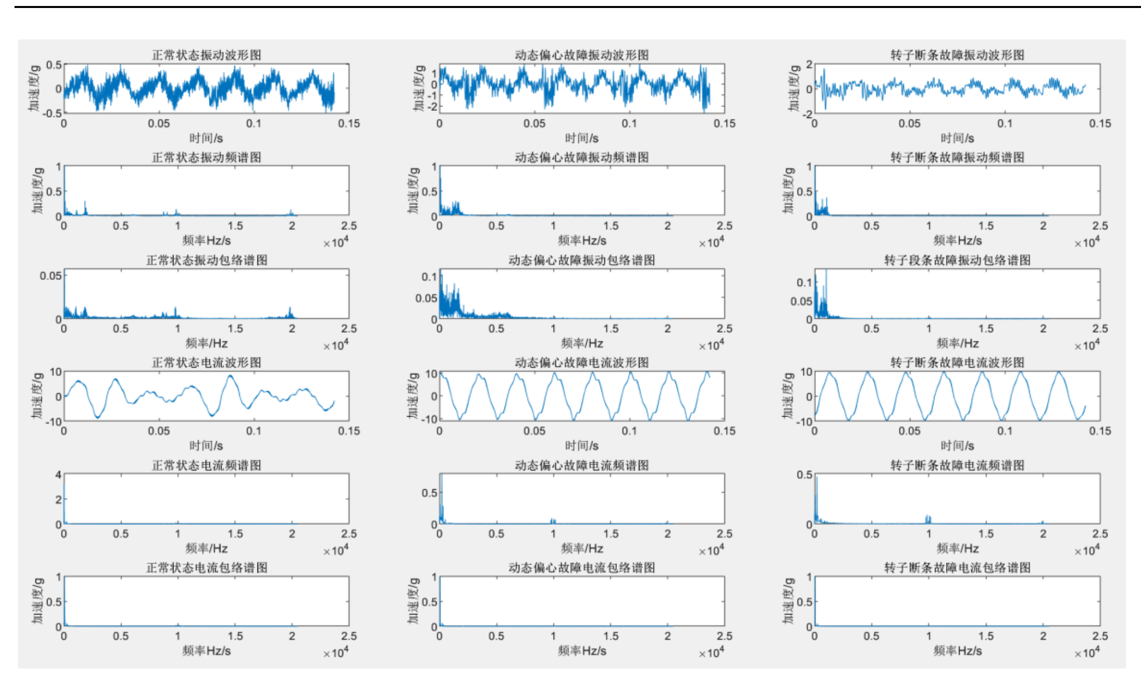


图 3-2 正常状态、动态偏心故障、转子断条故障原始数据及特征图

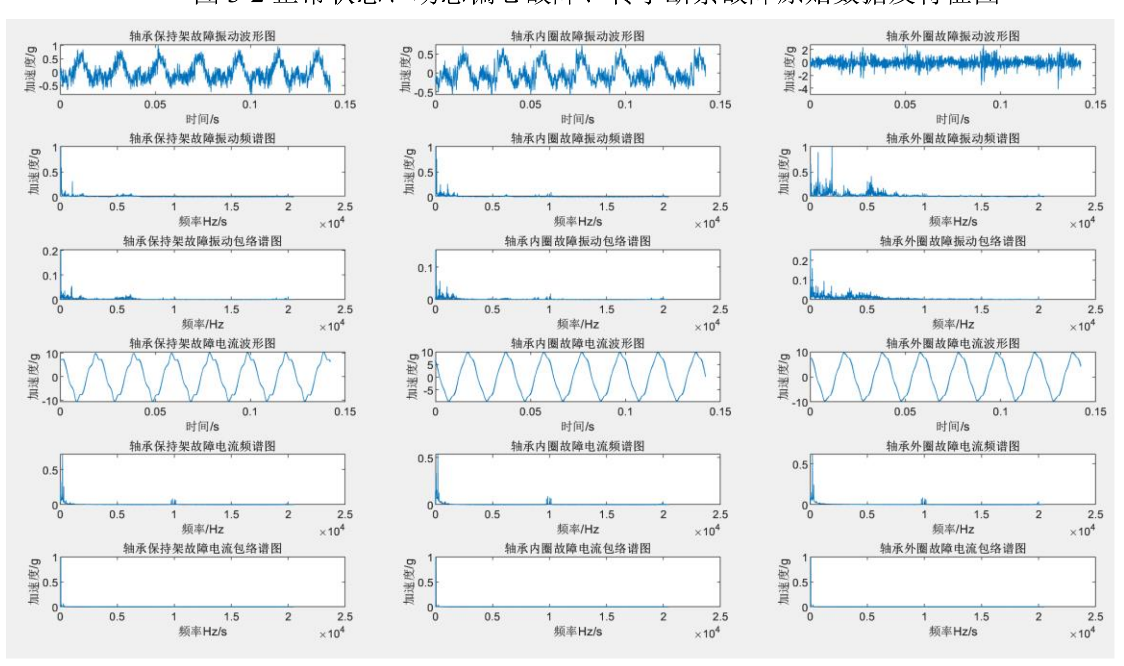


图 3-3 轴承保持架故障、轴承内圈故障、轴承外圈原始数据及特征图

3.4 基于数据融合与故障分类的神经网络设计

3.4.1 神经网络结构设计

电机故障诊断中常用监测方法有振动监测与电气监测，两种监测方法基本可以

覆盖电机常见的大部分机械和电气类故障，因此本文电机数据融合主要采用振动数据和电流数据，对电机进行故障识别与故障诊断。

针对本文实验数据，提出两个神经网络串联的方法，即建立深度卷积神经网络（Net1）和多层感知机（Net2）串联的神经网络，网络参数设计如下：

Net1 定义了一个双通道卷积神经网络模型，可以同时输入 2 维的振动、电流数据，用于进一步融合数据提取特征，具体结构如表 ：

表 3-3 Net1 卷积神经网络模型结构设置

结构	参数设置	功能
卷积层 conv1	输入通道数 2，卷积核大小 3，填充 1	捕捉不同尺度的局部特征
拟归一化层	归一化通道数 32	归一化每个通道的数据，有助于模型加速训练过程，提高收敛速度，并增强模型的鲁棒性
池化层	最大池化，下采样	减少特征图的维度和计算量，降低模型复杂性并提高计算效率
卷积层 conv2	输入通道数 32，卷积核大小 3，填充 1	捕捉不同尺度的局部特征
拟归一化层	归一化通道数 64	归一化每个通道的数据，有助于模型加速训练过程，提高收敛速度，并增强模型的鲁棒性
池化层	最大池化，下采样	减少特征图的维度和计算量，降低模型复杂性并提高计算效率
卷积层 conv3	输入通道数 64，卷积核大小 3，填充 1	捕捉不同尺度的局部特征

拟归一化层	归一化通道数 256	归一化每个通道的数据，有助于模型加速训练过程，提高收敛速度，并增强模型的鲁棒性
池化层	最大池化，下采样	减少特征图的维度和计算量，降低模型复杂性并提高计算效率
全连接层	输入特征数 256*91	将特征映射到指定维度，保留关键特征，使得模型更能够理解数据的语义和结构
Dropout 层	丢弃概率 0.5	随机丢弃一部分节点防止过拟合，也可以使模型更好地泛化到未见过的数据，提高模型鲁棒性

Net2 是一个多层感知机，用于故障的类型的识别分类，具体结构如表：

表 3-4 Net2 多层感知机网络模型结构设计

结构	功能
全连接层 fc1	将输入的特征向量映射到指定长度，引入线性变换
激活函数	使用 ReLu 作为激活函数，增强模型的非线性拟合能力
全连接层 fc2	将经过激活函数的隐藏层输出映射到指定类别的空间，进一步映射到最终的分类结果
Softmax 函数	将每个类别的输出归一化为一个概率值，用于分类问题

最终设计的故障诊断结构如图 3-4 所示：

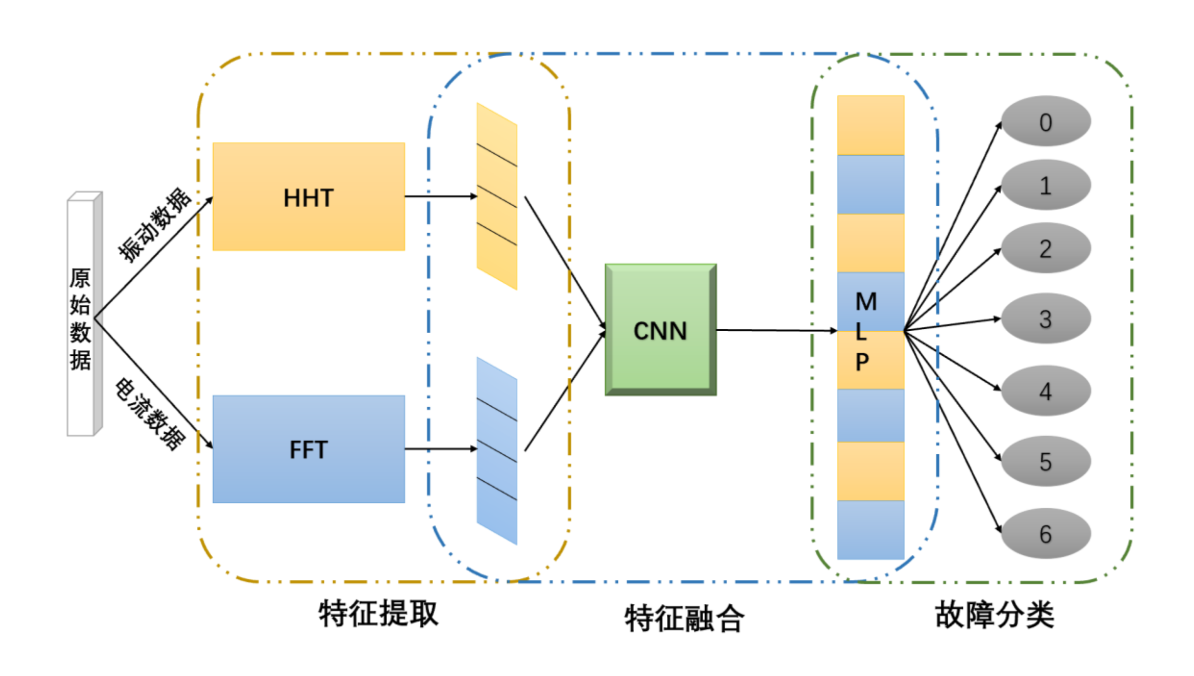


图 3-4 最终设计的故障诊断结构图

3.4.2 实验结果分析

3.4.2.1 神经网络融合分类效果验证：

取 HHT 提取包络谱的振动数据特征和 FFT 提取频谱的电流数据特征，按照 7：3 的比例划分训练集和测试集，输入搭建好的网络里，训练验证结果如下：

1、振动数据和电流数据融合，准确率和损失函数变化如图，在训练集上的准确率达到 76.9%

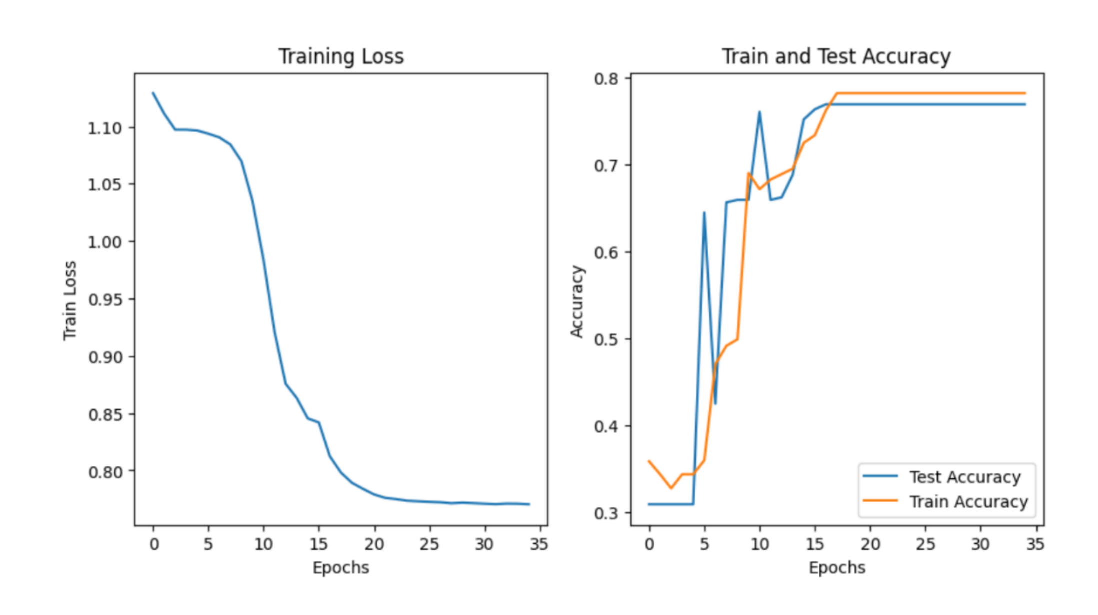


图 3-5 准确率和损失函数变化曲线图

2、仅使用振动数据特征，准确率和损失函数变化如图，在训练集上的准确率达到 68.3%，

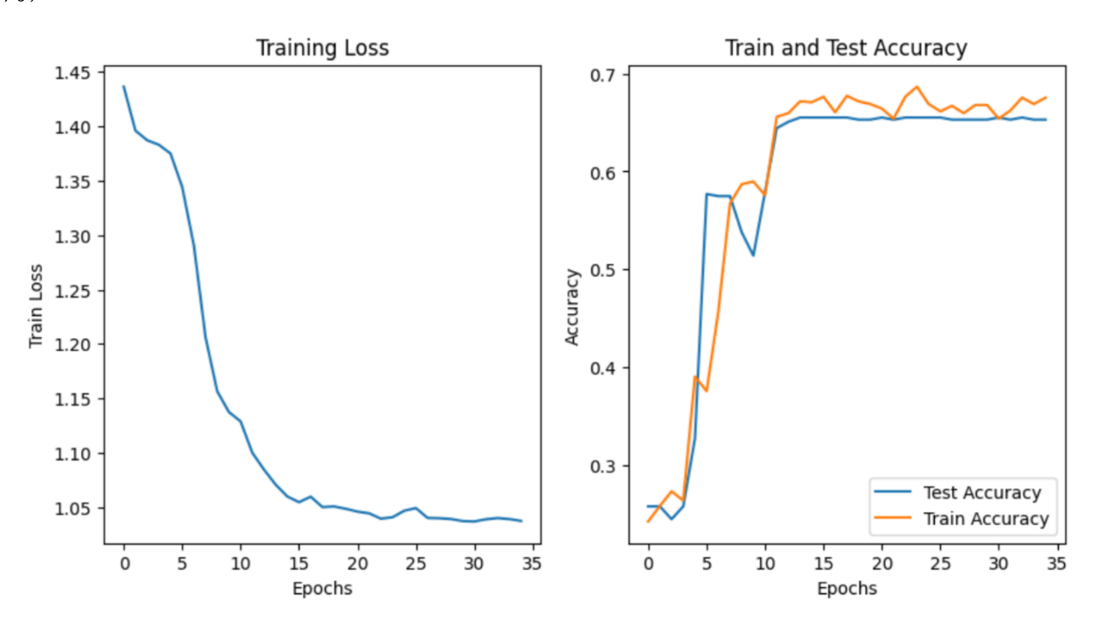


图 3-1 仅使用振动数据特征，准确率和损失函数变化

3、仅使用电流数据特征，准确率和损失函数变化如图，在训练集上的准确率达

到 58.7%

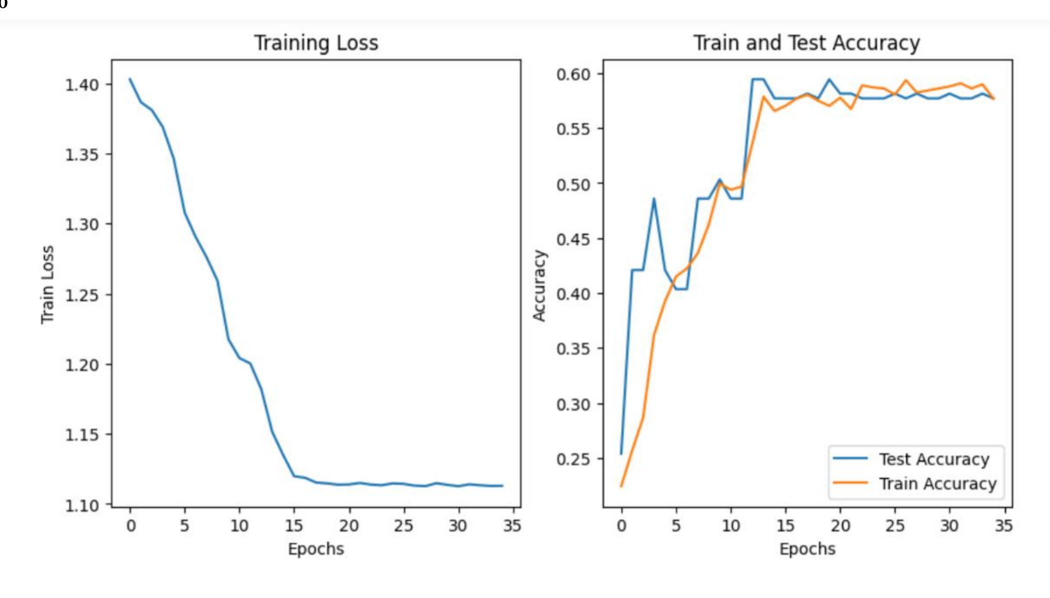


图 3-2 仅使用电流数据特征，准确率和损失函数变化

由于实验结果可能存在偶然性，进一步训练，进行了 5 次实验取平均值，实验结果如表所示

表 3-5. 神经网络融合分类效果验证表

数据选择	实验编号	分类准确率	平均准确率
使用振动、电流数据融合	①	80.3%	77.94%
	②	76.6%	
	③	76.9%	
	④	77.2%	
	⑤	78.7%	
使用振动数据	①	61.3%	67.2%
	②	66.4%	
	③	70.9%	
	④	69.1%	

	⑤	68.3%	
使用电流数据	①	58.7%	60.96%
	②	64.1%	
	③	59.4%	
	④	61.5%	
	⑤	61.1%	

由表中统计数据可得，使用振动数据电流融合后的平均分类准确率为 77.94%，仅使用振动数据的平均分类准确率为 67.2%，仅使用电流数据的平均分类准确率为 60.96%,这证明了使用的神经网络具有良好的数据融合及故障分类功能。

对融合前和融合后的数据提取特征，进行故障分类的可视化，效果如图 3-8，可以看到故障得到了较好的特征提取与融合。

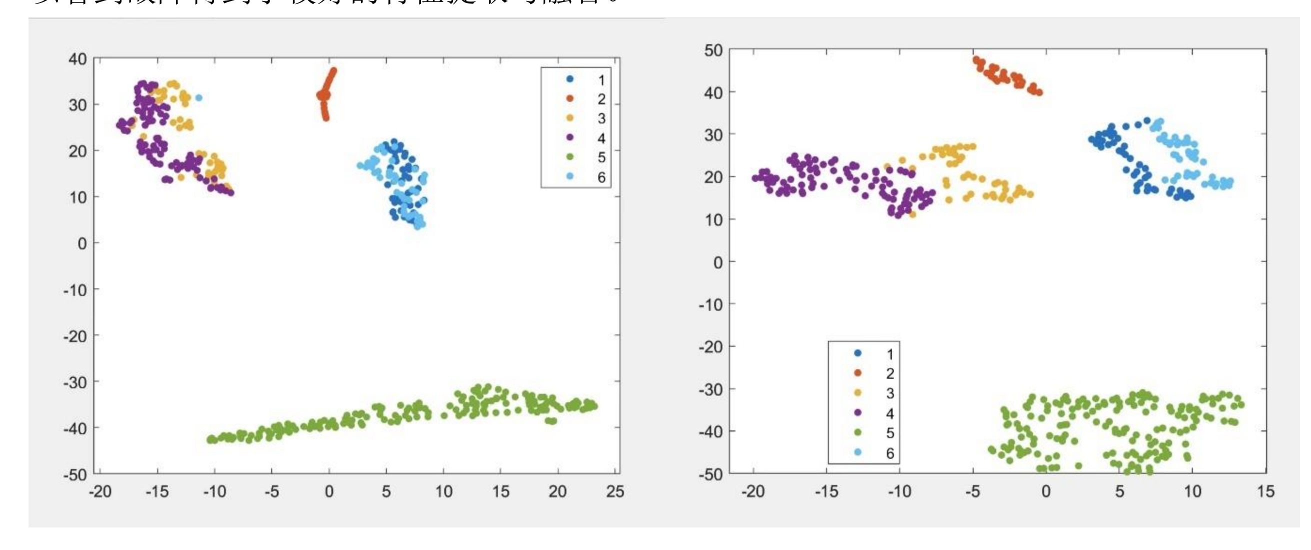


图 3-8 故障分类图

3.4.2.2 特征提取方法的选择与验证

为了验证提出的三种特征提取方案，构建了 3 个任务，由于实验结果可能存在偶然性，于是各进行 5 次数据融合及分类实验，统计准确率，如表 3-6 所示：

表 3-6. 特征提取方法验证实验表

数据选择	实验编号	分类准确率	平均准确率
振动数据使用 HHT 电流数据使用 FFT	①	80.3%	77.94%
	②	76.6%	
	③	76.9%	
	④	77.2%	
	⑤	78.7%	
振动和电流均使用 HHT	①	73.3%	69.92%
	②	70.6%	
	③	70.9%	
	④	68.5%	
	⑤	66.3%	
振动和电流均使用 FFT	①	68.7%	64.76%
	②	64.1%	
	③	60.4%	
	④	61.5%	
	⑤	69.1%	

发现结果与理论分析完全符合，振动数据使用 HHT 提取包络谱特征，电流数据使用 FFT 提取频谱特征，故障识别分类效果最好。

第 4 章 基于 RNN 和注意力机制的小样本故障诊断

在实际工业和生产环境中，获取大规模标记样本的成本往往较高，甚至不可行。因此，小样本故障诊断更符合实际应用场景，能够更好地适应实际数据的限制和难以获取大量样本的情况，还能够增强某一传感器失效后系统的鲁棒性。

在资源有限的情况下，小样本故障诊断方法能够更灵活地适应各种现实挑战对于小样本，他们要么利用正则化技术和模型的特征提取优势，要么基于真实样本的分布生成大量高质量样本，要么应用新兴的机器学习技术。大卷积核的设计有利于增强鲁棒性[25]，而深小卷积核的有效提取抽象特征。此外，在振动信号中不能忽略时间步长信息，所以与 CNN 相比，RNN 刚好可以满足要求。

因此，在之前故障诊断方法的基础上继续学习深度学习相关知识，提出双卷积层用于提取信号的高低频特征，注意机制通过分配权重对融合后的特征进行加权，关注主要频谱，接着，RNN 用于获取不同时间序列位置的隐藏信息的小样本故障诊断方法。

4.1 循环神经网络（RNN）及其衍生网络

一般 RNN 的数据分析依据时间序列来进行，需要参考前一时刻的数据预测未来数据的变化，当数据处理需要联系前后时刻或者数据对时间依赖性较强时，这样的网络结构往往会产生较大的误差。此外，这类神经网络的训练需要大规模的训练样本，如果训练样本中的元素较少，那么很可能难以得到理想的模型[18]。为此，本文在原有 RNN 模型的基础上，增加了一条反向时序的 RNN，两条 RNN 在同一时刻共享输入层和输出层。Bi-RNN 结构图如图 4-1 所示：

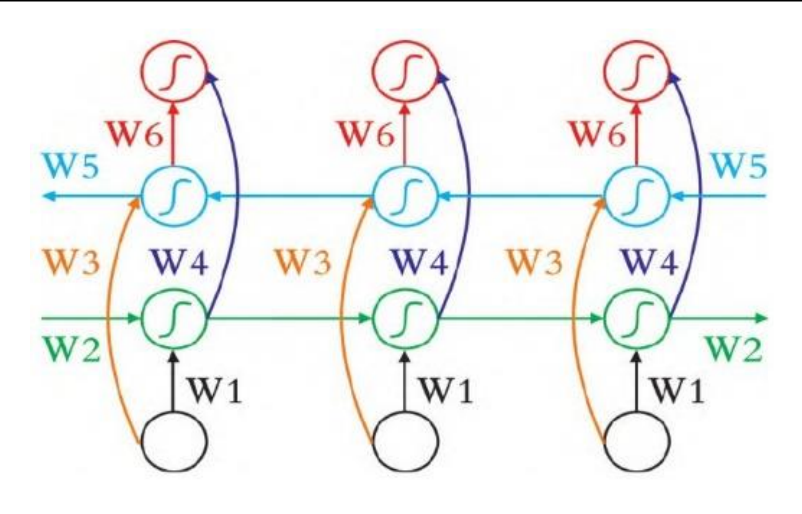


图 4-1 RNN 结构图

4.2 双路径卷积与特征融合

双重卷积层结构采用了两个不同的路径来提取信号的高低频特征。第一条路径使用两个较大的卷积核，旨在学习信号的低频特征。较大的卷积核在文献中被证明可以增强模型对噪声的鲁棒性。第二条路径采用小卷积核，通过集成四个非线性激活层深化神经网络，从而提高模型的判别能力。最终通过逐元素乘法实现特征的融合，确保每个通道都包含丰富的信息。

AdaBN 被引入以提高模型对不同领域的适应性。它取代了传统的批标准化（BN），通过调整从源领域到目标领域的统计信息，以增强模型的泛化能力。

4.3 注意力机制

注意力机制是一种神经网络模型中的关键技术，旨在使模型能够在处理序列或集合数据时更加灵活地关注重要的部分，从而提高模型的性能。基本结构如图 4-2 所示：

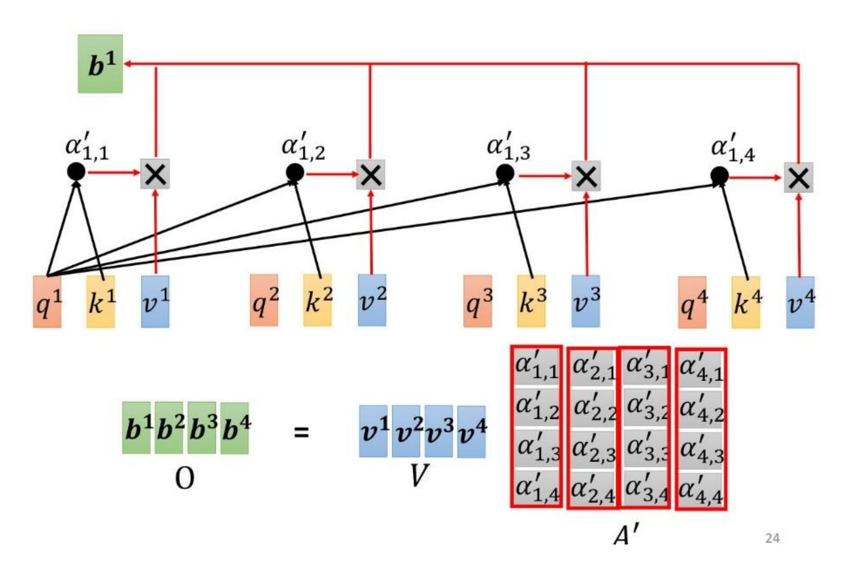


图 4-2 注意力机制的基本结构

主要包括以下两部分：

1、上下文权重分配： 注意力机制通过为输入序列中的每个元素分配不同的权重，使模型能够聚焦于当前任务关注的信息。

2、自适应性： 允许模型自适应地调整每个元素的重要性，以适应不同的输入情境。

注意力机制是一种强大的技术，我们可以赋予其不同的结构从而灵活地关注输入序列中的重要部分，提高了神经网络在处理序列和集合数据时的性能和效率，其应用广泛，为小样本故障诊断提供了更强大的建模能力。

4.4 神经网络结构设计

提出了一种小样本的故障诊断方法，该方法由数据增强、双路径卷积、注意力机制、Bi-RNN、GAP 和诊断层组成，如图 4-3 所示：

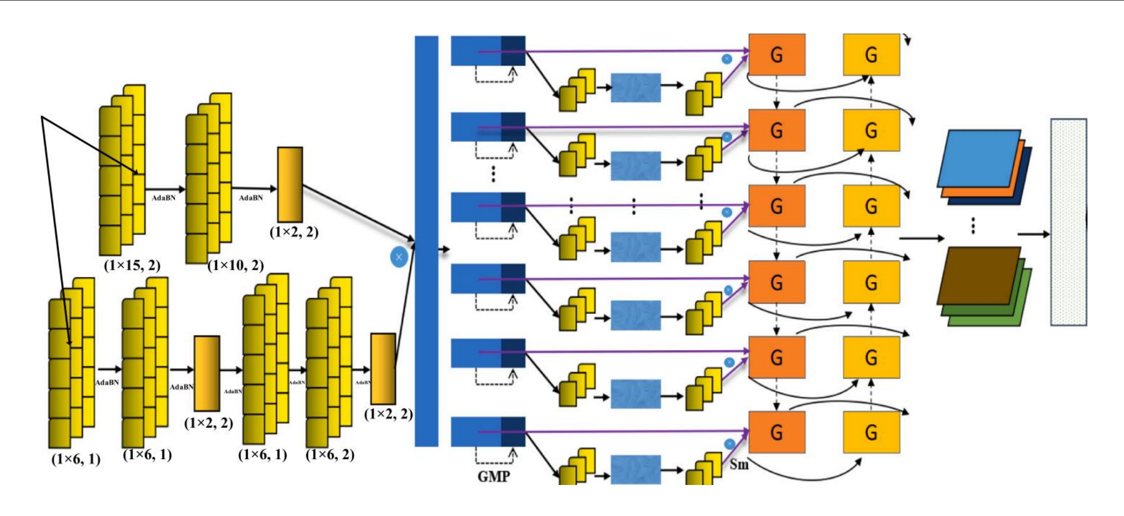


图 4-3 整体网络结构图

根据第三章介绍的实验数据，在仅使用振动数据或仅使用电流数据的情况下，准确率高达 99%，且用时很短，具有诊断效率优势，如图 4-5 及 4-6 所示：

```
epoch: 87, Train Loss: 0.5495, Train Acc: 1.0000, Test Loss: 0.6830, Test Acc: 0.9733
EarlyStopping counter: 5 out of 10
epoch: 88, Train Loss: 0.5488, Train Acc: 1.0000, Test Loss: 0.6587, Test Acc: 0.9933
EarlyStopping counter: 6 out of 10
epoch: 89, Train Loss: 0.5490, Train Acc: 1.0000, Test Loss: 0.6235, Test Acc: 0.9967
EarlyStopping counter: 7 out of 10
epoch: 90, Train Loss: 0.5488, Train Acc: 1.0000, Test Loss: 0.5859, Test Acc: 0.9967
EarlyStopping counter: 8 out of 10
epoch: 91, Train Loss: 0.5484, Train Acc: 1.0000, Test Loss: 0.5627, Test Acc: 1.0000
EarlyStopping counter: 9 out of 10
epoch: 92, Train Loss: 0.5484, Train Acc: 1.0000, Test Loss: 0.5545, Test Acc: 1.0000
EarlyStopping counter: 10 out of 10
Early stopping
time: 227.3735 s
```

图 4-5 训练结果

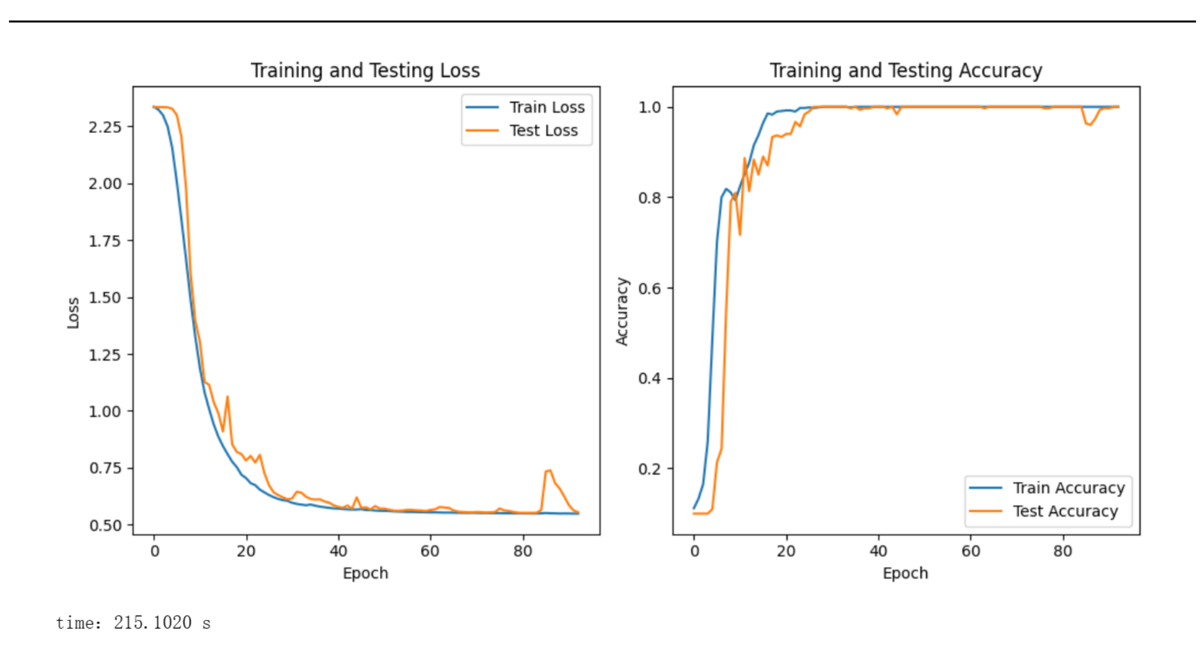


图 4-7 训练准确率及 loss 变化图

实现了基于小样本的故障诊断设想，为实际工业场景中的故障检测提供了可靠的解决方案，具有较高的准确性、快速的效率以及对小样本数据的良好适应性。

附录

文中所有代码已上传至 github，地址为 https://github.com/itsnot11/deeplearning.git

两个实验的数据均涉密，没有上传。

第一个数据融合网络提交了 CNN,MLP 以及训练和测试模块的所有代码。

第二个小样本故障诊断网络提交了最主要的三块代码：激活函数、注意力机制以及 Adamp 优化器的实现。